

# Сети глубокого обучения для построения виртуальных датчиков технологических процессов нефтепереработки

---

АСПИРАНТ 2 Г.О. ЛАЗУХИН И.С.,  
К.Ф-М.Н., ДОЦЕНТ ПЕТРОВСКИЙ М.И.,  
Д.Ф-М.Н., ПРОФЕССОР МАШЕЧКИН И.В.

# Актуальность. Цифровые двойники

---

## Современный производственный комплекс:

- Один или несколько технологических процессов (синтез выходов-продуктов)
- Повсеместный мониторинг и запись показаний физических датчиков системы
- Лабораторный анализ показателей качества продуктов
- Управление системой на основе дифференциальных линейных моделей

## «Цифровой двойник»:

- Производственный процесс как *временной ряд*
- Точные *прогнозные модели* производственных процессов;
- Оптимальное управление на основе моделей
- Визуализация зависимостей, прогнозов, результатов управления

# Лабораторные данные

---

**Физические данные** – показания датчиков системы, получаемые в режиме онлайн

**Лабораторные данные** – показания лаборатории, не могут быть получены физическим датчиком:

- Не могут быть получены точно в каждый заданный момент времени, *разреженные данные*. Типичный период сбора показаний – раз в сутки
- Критически важная составляющая процесса – *показатели качества* продукции
- Существующие интерполяции, используемые в производстве: *линейные и кусочно-постоянные аппроксимации*.

**Виртуальные анализаторы** (англ. *Soft Sensors*) – дополненные в каждый момент времени, тем или иным способом, лабораторные данные.

*Пример: октановое число продукта на выходе номер 1.*

# Данные. Виртуальные анализаторы

Размерность набора данных	8569 на 322
MV переменных	5
LAB переменных	33
Период показаний	01.10.2022-23.09.2023
Частота показаний	1 час

Целевая переменная	
Объем показаний	326
Периодичность	24 часа
Воспроизводимость	3.5 градуса

Набор данных<sup>1</sup>, предоставленный для построения виртуальных анализаторов:

- Сильная *коррелированность* как физических так и лабораторных показаний
- Критически *небольшой объем показаний* целевой переменной
- *Воспроизводимость показаний* – средняя «погрешность» лабораторных исследований

Авторами исследовалась *задача получения химических показателей производственного процесса в режиме онлайн на основе значений физических датчиков*

<sup>1</sup>A data set provided to the Moscow State University by the PJSC Lukoil Oil Company as a part of the corresponding research contract No. ИТС 1-22-26сп dated 16.10.2023.

# Задача моделирования

---

*Дискретная сетка* во времени:

$$T = t_1, t_2, \dots, t_M, \text{ где } t_{i+1} - t_i = \tau = \text{const}$$

*Технологический набор данных*:

$$F(t) = f_1(t), f_2(t), \dots, f_N(t), \text{ пусть } X = \{f_j(t_i)\}_{M \times N}$$


*Многомерная модель технологического процесса* во времени:

$$X_{t+k}, \dots, X_{t+k-r} \approx \tilde{F}(X_t, \dots, X_{t-r}), \text{ где } t \geq r$$


В случае сырых лабораторных данных,  $f_{lab}(t)$ , соответствующая лабораторной переменной  $lab$ , будет иметь пропуски ( $NaN$ ), что будет учтено при обучении конкретных моделей  $\tilde{F}$  путем отсеивания таких тренировочных векторов

# Подготовка данных. Распределение

## РАСПРЕДЕЛЕНИЕ ЦЕЛЕВОЙ ПЕРЕМЕННОЙ



## ПЕРИОДИЧНОСТЬ СБОРА ПОКАЗАНИЙ



# Подготовка данных. Периоды стабильности



ИСХОДНЫЕ ПОКАЗАНИЯ ЦЕЛЕВОЙ ПЕРЕМЕННОЙ





ПОЛУАВТОМАТИЧЕСКИЙ ОТБОР ПЕРИОДОВ СТАБИЛЬНОСТИ



# Подготовка данных. Интерполяция




В качестве основных методов базовой интерполяции были выбраны **Сплайн** второго порядка (*сверху слева*) и **Loess**-сглаживание (*сверху справа*). Линейная интерполяция (*снизу слева*) и гауссово ядро (*снизу справа*) так же были рассмотрены, но не зарекомендовали себя в рамках основного набора данных



# Отбор признаков (1)

Специфика задачи:

- Сильная корреляция внутри набора показаний физических переменных
- Необходимость со стороны технологов в явном представлении зависимостей между переменными
- Необходимость учитывать мнение эксперта области при построении моделей




Ненулевые попарные коэф-ты корреляции физических переменных набора

# Отбор признаков (2)

Метод	Описание	Пороговая метрика	Простота
PLS-кластеризация	Иерархическая кластеризация на основе регрессии главных компонент	Глубина кластеризации	1 гиперпараметр
Сети Байеса	Авто-генерируемые сети Байеса с корнем в узле целевой переменной	Глубина обхода корня	1-2 гиперпараметра
StemGNN	Графовая нейросетевая модель с механизмами внимания	Число переменных	1-2 гиперпараметра
Регуляризация на основе отклика	Штраф модели на основе модуля корреляции с целевой переменной	-	2 гиперпараметра
Ансамбли деревьев	Важность признаков на основе числа вхождений в ансамбль деревьев	Число вхождений	1+ гиперпараметров
LASSO	Важность признаков как модуль весов LASSO модели.	Число переменных	1 гиперпараметр
Корреляция (baseline)	-	-	-

# Отбор признаков. Временная компонента

- 1. Неявная.** Попарные корреляции с переменным сдвигом целевой и физических переменных для моделей, не учитывающих временную компоненту в явном виде. Исследуется переменная, сдвинутая во времени до своей наибольшей корреляции с откликом (*PLS, Bayes, Lasso, регуляризация на основе отклика*).
- 2. Явная.** Исследуются явные зависимости во времени между физическими и лабораторными переменными, двумерное пространство признаков вида {<переменная, лаг>} (*Ансамбли деревьев*).
- 3. Автоматическая.** Компонента времени учитывается внутри модели без дополнительного внимания со стороны пользователя (*StemGNN*).




Корреляция переменных с откликом в зависимости от времени

# Отбор признаков. PLS-кластеризация

Экспертные переменные выбираются как главные в кластерах, построенных по разбиению на главные компоненты

## Характеристики:

- Общий/групповой/индивидуальный отбор;
- Неявная компонента времени;
- Дендрограмма как визуальная интерпретация;
- Учитывается мнение эксперта офлайн (т.е. во время построения моделей);
- Гарантированное включение обязательных переменных;
- Гиперпараметры (1): порог обрезания дерева.




Визуализация работы с PLS

# Отбор признаков. Сети Байеса

Отбор по поддеревьям, построенных по *Chow-Liu* с корнем в целевой переменной

## Характеристики:

- Индивидуальный отбор;
- Неявная компонента времени;
- Древесное представление зависимостей;
- Учитывается мнение эксперта офлайн;
- Гарантированное включение обязательных переменных;
- Гиперпараметры (1-2): число отобранных признаков [, порог p-value].



Визуализация работы с деревьями

# Отбор признаков. StemGNN

Отбор на основе графовой нейросети, использующей механизмы внимания *StemGNN*. Модификация: ложный вход для лабораторных данных. Только интерполированные данные.

## Характеристики:

- Общий контекстуальный во времени отбор переменных;
- Автоматическая временная компонента – отсутствует лаг как параметр;
- Визуализация зависимостей в виде теплокарты внимания;
- Учитывает мнение эксперта онлайн/офлайн;
- Гарантированное включение обязательных переменных;
- Опциональная трансформация признаков;
- Гиперпараметры (0-2): [число слоев] [, число переменных].




Figure 1: The overall architecture of Spectral Temporal Graph Neural Network.

*StemGNN* в оригинальной статье

# Виртуальные анализаторы. Отбор признаков. Регуляризация

---

Вектор корреляции (выбранного типа) физических и лабораторных показаний (индивидуально) как множитель для *регуляризации нейросетевой модели* лабораторных исследований. Эксперт опционально проставляет единицы для физически значимых зависимостей.

## Характеристики:


- Индивидуальный отбор;
- Неявная временная компонента;
- Теплокарта корреляций как визуализация зависимостей;
- Учитывает мнение эксперта офлайн;
- Гарантированное включение обязательных переменных;
- Неявное воздействие на участвующие переменные;
- Гиперпараметры (2): тип корреляции, множитель регуляризации.

# Виртуальные анализаторы. Отбор признаков. Ансамбли деревьев

Градиентный бустинг для отбора (*LightGBM*)

## Характеристики:

- Индивидуальный отбор;
- Явная временная компонента (отбор по матрице шаг времени-переменная);
- Теплокарта важности в модели как визуализация зависимостей;
- Негарантированное включение обязательных переменных;
- Гиперпараметры (1): число отобранных переменных (порог отбора).



Теплокарта зависимостей для лагов

# Отбор признаков. Эксперимент


Переменные	PLS	Bayes	Lasso	LGBM	StemGNN
	0,865768	4	0,045041	3	
		4	0,029486		0,947341
	0,963523	4	0,123929		
		2	0,034464		0,334994
	0,79364	1		3	
		4		2	0,414463
	0,994848		0,032323		
	0,930119	2			
		3	0,137878		
	0,979286	4			
		4	0,203014		
		3	0,021009		
		2			0,361444
		3	0,001983		
		4	0,05296		
	3	0,017038			

# Прогнозирование

Метод	Описание	Данные для обучения
Базовая модель MLP+Boosting	Полносвязная нейросетевая модель (baseline модель)	Исходный ряд
Простая RNN модель	Простая рекуррентная модель с масштабирующим слоем (простая модель)	Исходный ряд/Spline/LOESS
Seq2seq	Рекуррентная многошаговая модель для физических переменных в ансамбле с полносвязной моделью лаб. исследований (модель прогноза на несколько шагов)	Spline/LOESS
StemGNN	Сложная GNN модель, использующая механизмы внимания (известная сложная модель)	Spline/LOESS
GAN	Генеративно-сопоставительная сеть, создающая новые тренировочные образцы в процессе обучения (модель борьбы с небольшим тренировочным набором)	Исходный ряд


# Прогнозирование. Простые модели

**Отбор переменных MLP:** ансамбли деревьев (*LightGBM*) – плоские признаки на входе




Подобранная архитектура (1)

**Отбор переменных RNN:** *StemGNN, PLS, Lasso, Bayes*, регуляризация по отклику





Подобранная архитектура (2)



Подобранная архитектура (3)

# Прогнозирование. Sequence-to-Sequence


Разновидность модели<sup>3</sup> векторного (в частном случае – пошагового) прогноза физических данных (напр. RNN-RNN). Одновременно обучается более простая модель (MLP) прогнозирования лабораторных исследований, использующая выходы *Seq2Seq* модели как признаки.



<sup>3</sup>Hong, Seokyoung, et al. "A dynamic soft sensor based on hybrid neural networks to improve early off-spec detection." *Engineering with Computers* 39.4 (2023): 3011-3021.

# Прогнозирование. GAN

Рекуррентный регрессор, обучаемый в рамках GAN. **Отбор переменных:** *StemGNN, PLS, Lasso, Bayes*



Подобранная архитектура генератора

Подобранная архитектура дискриминатора и регрессора

# Прогнозирование. Эксперимент (1)

---

- TRAIN:TEST = 6:4
- Исследуемые методы: *MLP, StemGNN, RNN (small/large), GAN, Seq2Seq*
- Исследуемые методы отбора: *Corr+PLS, Corr+Bayes, Corr+Lasso, StemGNN, LightGBM*
- Максимальный лаг моделей при построении пространства признаков: 24 часа
- Исследуемые методы интерполяции (<24 часов): *Spline, LOESS*
- Шаг моделей: 1 час вперед от последнего известного значения физических переменных;
- Задача: аппроксимация + прогноз.
- Отбор моделей: *p-value* корреляции (адекватность), положительный *R2*, *RMSE*

# Виртуальные анализаторы. Прогнозирование. Эксперимент (2)



StemGNN - Loess

StemGNN (Lasso) - Spline


Лабораторные показания




Лабораторные показания



Residuals



Residuals





# Виртуальные анализаторы. Прогнозирование. Эксперимент (3)

RNN BIG (Bayes)



RNN SMALL (Bayes)





# Виртуальные анализаторы. Прогнозирование. Эксперимент (4)



MLP (LightGBM)

GAN (LightGBM)



# Виртуальные анализаторы. Прогнозирование. Эксперимент (5)



S2S (Bayes) - Loess



# Результаты

---

- Были предложены несколько подходов, объединяющих задачи прогноза и заполнения пропусков для моделирования лабораторных исследований. Рассмотрены методы отбора признаков на основе PLS регрессии (иерархическая кластеризация), градиентного бустинга, деревьев Байеса, графовой нейронной сети, базовые методы в виде Lasso и корреляций. Каждый из предложенных методов отбора был адаптирован для возможности учитывать экспертное мнение специалистов области
- Были предложены методы прогнозирования лабораторных исследований на основе графовых нейросетей, генеративных подходов, полносвязных и рекуррентных сетей, рассмотрены аппроксимации отклика с использованием LOESS и сплайнов, а также вариант регуляризации, учитывающей корреляцию с откликом
- Полученные авторами экспериментальные результаты показывают преимущество использования для данной задачи простых рекуррентных сетей, графовых нейросетей с предварительной интерполяцией, отбора признаков на основе деревьев Байеса. Был предложен комбинированный подход, учитывающий адекватность модели, корреляцию ее с истинными значениями лаборатории и стандартные ошибки

# Публикации

---

## Статьи:

- Lazukhin I. S., Petrovskiy M. I., Mashechkin I. V. Deep Learning Methods for Tasks of Creating Digital Twins for Technological Processes //Moscow University Physics Bulletin. – 2023. – Т. 78. – №. 1. – С. S3-S15.

## Доклады:

- 2023 Deep learning methods for the tasks of creating "digital twins" for technological processes (Приглашенный), Авторы: Petrovskiy Mikhail, Lazuhin Ivan, The 7th International Conference on Deep Learning in Computational Physics DLCP23, Санкт-Петербург, Россия, 21-23 июня 2023;
- 2023 Дискретная модель оптимального управления при ограничениях на основе (Устный), Авторы: Машечкин И.В., Петровский М.И., Лазухин И.С., Ломоносовские чтения - 2023, Секция вычислительная математика и кибернетика, 4-14 апреля 2023, Москва, МГУ, факультет ВМК, Россия, 4-14 апреля 2023.

Спасибо за внимание!

---

# StemGNN

**StemGNN<sup>2</sup>** (Attention для признаков + Graph Neural Networks) – попытка объединить использование темпоральных и межпризнаковых зависимостей в одной архитектуре. Рассматривают задачу прогноза как исследование графа связей между признаками. В задаче прогноза на несколько шагов предлагают использовать карточный подход, т.е. последовательно прогнозировать и подавать выход прогноза на вход для расчета следующего шага. Используется дополнительный выход модели для автоэнкодинга.

Темпоральные связи обрабатываются с помощью графового преобразования Фурье (GFT), разлагая по базису собственных значений лапласову матрицу графа.

Так же используется предложенный блок Spe-Seq Cell (имплементирующий дискретное преобразование Фурье – DFT) для разложения выходов GFT по частотному базису.




Figure 1: The overall architecture of Spectral Temporal Graph Neural Network.

# Метрики, объединенные по лагам и шагам

feature	model	metric	data	rmse	mae	mape	r2	Pearson (p-value)	hinge
-	RNN_BIG	mse	loess	2,535649	1,907155	0,005158	-0,63966	0,78063	0,211197
-	RNN_REG	mse	raw	4,863678	3,567031	0,009662	0,147436	0,922943	1,241325
BAYES	S2S	mse	loess	5,305752	4,21272	0,011398	-1,84303	0,994548	1,560256
-	STEMGNN	mse	loess	5,311611	4,181584	0,011313	-0,1593	0,970011	1,685108
AE	MLP_GREEDY	mse	raw	5,800053	4,234657	0,011468	-0,27718	0,990812	1,751397
AE	MLP	mse	raw	6,823525	5,07043	0,013702	-0,51792	0,945529	2,447496
BAYES	S2S_REG	mse	loess	6,93979	6,517621	0,017634	-0,52716	0,990655	3,181237
PLS	RNN_SMALL	mse	raw	7,070208	5,315755	0,014364	-0,25371	0,625487	2,608204
AE	GAN	mse	raw	14,78332	11,11681	0,03006	-2,14625	0,680998	8,005231
LASSO	GAN_RNN	mse	raw	16,20799	12,94707	0,035028	-2,14692	0,998559	9,712436